一种提升功能磁共振成像分析时间敏感性的插件式图神经网络

Irmak Sivgin[a,b,*]，Hasan A. Bedel[a,b,*]，S¸aban ¨Ozt¨urk[a,b,c]，Tolga C¸ukur[a,b,d,**]

[a]土耳其安卡拉 *06800*，比尔肯特大学电气与电子工程系[b]土耳其安卡拉 *06800*，比尔肯特大学国家磁共振研究中心（*UMRAM*）[c]土耳其阿马西亚 *05100*，阿马西亚大学电气电子工程系[d]土耳其安卡拉 *06800*，比尔肯特大学神经科学项目

文章信息

关键词：功能磁共振成像，时间序列，神经网络，图，分类，连接性

arXiv:2301.00439v1 [eess.SP] 1 Jan 2023

摘要

近年来，基于学习的方法使高维功能磁共振成像（fMRI）时间序列分析的性能实现了飞跃。文献中普遍采用深度学习模型，将脑区之间的功能连接特征作为输入。然而，许多模型关注扫描期间静态不变的功能连接特征，降低了对脑活动动态特征的敏感性。本文介绍一种插件式图神经网络，可灵活集成到主学习型fMRI模型中，以提高其时间敏感性。该方法将脑区作为节点，并将血氧水平依赖（BOLD）信号作为节点输入。所提出的GraphCorr方法采用基于Transformer编码器的节点嵌入模块，以捕获BOLD信号经时间窗口处理后的潜在表示。GraphCorr还采用滞后滤波模块，通过计算窗口化BOLD信号在一系列时间滞后下的互相关，考虑节点间的延迟交互。两个模块捕获的信息通过在图上执行的消息传递算法进行融合，随后在输出端计算增强的节点特征。利用这些增强特征驱动后续的基于学习的模型，从而以更高的敏感性分析fMRI时间序列。在两个公开数据集上的全面实验表明，对于若干将GraphCorr生成的fMRI时间序列特征表示作为输入的先进图方法和卷积方法，该方法提升了分类性能和可解释性。

© 2023

1. 引言

人脑由多个脑区构成，这些脑区在认知过程中相互作用并处理信息 [1]。反过来，单个功能网络中的相关活动与特定的心理状态有关 [2, 3]。功能磁共振成像（fMRI）是一种强大的研究功能网络的成像手段，因为它能够以较高的时空分辨率无创测量神经活动所产生的全脑血氧水平依赖（BOLD）信号 [4, 5]。在fMRI研究中，功能连接（FC）指标用于评估不同脑区之间BOLD信号的相似性 [6, 7, 8, 9, 10]。随后，将FC指标映射到心理状态的传统方法，是采用逻辑回归和支持向量机（SVM）等常规方法 [11, 12, 13, 14]遗憾的是，常规方法往往对复杂的信息模式不够敏感全脑功能磁共振成像时间序列中的复杂信息模式 [15]。

近年来，深度学习（DL）模型在探索高维数据集特征方面取得了成功，这促使研究者将其用于功能磁共振成像分析，作为传统方法的替代方案 [16, 17, 18, 19, 20]。该领域早期的尝试提出了浅层多层感知机（MLP） [21, 22]和玻尔兹曼机（BM）模型 [23, 16]。后续研究采用了基于卷积神经网络（CNN） [24, 17, 25], 、图神经网络（GNN）[26, 18, 27, 28, 29, 30], 和 Transformer [31, 32, 33, 34, 35]模型的更深层架构，以提升性能。通常，这些模型首先根据解剖或功能图谱[36, 37, 38], 构建一组对应脑区的节点，并将基于脑区间功能连接强度的输入特征提供给这些节点 [39, 18]。一种常见做法是采用静态功能连接特征，其来源是对整个 fMRI时间序列持续时间内的相关性度量进行汇总 [40, 18]。然而，这种方法不足以

*共同贡献

**通讯作者，电子邮箱：cukur@ee.bilkent.edu.tr

捕捉静息态或认知任务期间人脑中动态的区域间相互作用 [41]。尽管近期已有替代策略用于评估功能连接特征的时间变异性，但这些方法通常考察时间序列局部时间窗口内的瞬时信号相关性 [42, 43, 44]。因此，这些方法缺乏明确机制来捕捉脑区之间的延迟相关性；由于大脑中的层级认知加工或血氧水平依赖测量中的血流动力学延迟，这类相关性可能出现在 fMRI时间序列中 [45]。

在本研究中，我们提出了一种可插拔图神经网络 GraphCorr，它能够为基于学习的功能磁共振成像模型提供增强的输入特征，从而提高模型对动态、滞后的区域间相互作用的敏感性。为捕捉相互作用的动态变化，GraphCorr采用一种基于Transformer编码器的新型节点嵌入模块，用于计算时间序列中窗口化血氧水平依赖信号的层次化嵌入。为捕捉脑区之间的滞后相互作用，GraphCorr采用一种新型滞后滤波模块，用于计算不同时间延迟范围内成对节点互相关的非线性特征。图模型以节点嵌入模块生成的嵌入作为节点特征，并以滞后滤波模块生成的滞后特征作为边权重进行初始化。随后，利用消息传递算法计算增强的节点嵌入，以反映动态、滞后的区域间相互作用。

在此，我们展示了GraphCorr在两个公开数据集的功能磁共振成像扫描性别分类任务中的应用：人类连接组计划（HCP）数据集 [46] 以及来自Amsterdam Open MRI Collection（AOMIC）的ID1000数据集 [47]。GraphCorr作为插件与功能磁共振成像分析领域的先进基线模型相结合，包括SAGE [48], BrainGNN [18], BrainNetCNN [17] 和图卷积网络 [29]。与GraphCorr结合后，各基线模型的性能均显著提升。我们设计了一种针对GraphCorr的解释性分析方法，用于识别对分类决策贡献最显著的时间帧和脑区。结果表明，GraphCorr提升了基线模型的可解释性，其生成的解释与文献中重要的神经科学发现更加吻合。我们还展示了GraphCorr衍生特征的优势，并将其与通过可插拔循环神经网络（RNN）提取的特征，以及直接从血氧水平依赖信号计算得到的动态功能连接特征进行了比较。

2. 相关工作

认知过程会在人脑中引发广泛分布的响应模式 [49]。反过来，通过分析由此产生的多变量血氧水平依赖信号，可以解码刺激或任务变量等与过程相关的信息 [50, 51]。该领域的早期研究采用了相对简单的传统机器学习（ML）方法进行功能磁共振成像分析 [41, 52]。这些传统方法高度依赖特征选择流程，以应对功能磁共振成像数据固有的高维度 [53]。可以说，脑区之间的功能连接特征是最常用于捕捉认知过程判别性信息的特征 [21, 17, 39, 18]。许多研究报告称，利用受试者静息态 [54, 55],认知任务 [11, 18],或两者兼具 [14]时的功能连接特征，可以检测外部变量或疾病状态。

鉴于功能连接特征此前在功能磁共振成像分析中取得了成功，近年来的深度学习方法也广泛采用了这些特征，并借助更复杂的模型提升性能 [56,57]。一种常见的基于深度学习的功能磁共振成像分析方法，将静态功能连接特征作为模型输入，其中，一对脑区之间的功能连接被视为整个扫描过程中其血氧水平依赖信号的总体相关性。为了提取这些特征的层次化潜在表示，早期研究提出了两类方法：一类是相对紧凑的全连接架构，包括 BM 和多层感知机模型 [23, 16, 21, 22], ；另一类是计算效率较高的深层架构，包括卷积神经网络模型 [25, 17]。鉴于图神经网络模型天然适用于分析具有内在连接结构的功能磁共振成像数据，后续研究也对其进行了探索 [58,59, 60, 61, 18]。这些深度学习方法均显著提升了功能磁共振成像分析相较于传统方法的性能。然而，以静态功能连接特征为基础的分析，对 fMRI 时间序列中细粒度时间信息的敏感性仍可能不足 [12, 25]。

为提高时间敏感性，已有研究提出了多种替代策略，将时变特征引入用于功能磁共振成像分析的深度学习模型。一类方法基于标准相关性度量，在时间序列的滑动窗口上预先计算功能连接特征，并将各窗口的特征拼接起来，形成更高维的输入 [62, 63, 28, 43, 44]。尽管这些动态功能连接特征有望提升时间敏感性，但其固有维度会增加复杂度，从而可能降低模型性能。另一类方法则通过卷积神经网络模块对体素级血氧水平依赖信号进行空间编码，再利用循环神经网络或 Transformer 模型处理空间编码后的血氧水平依赖信号，以提取时变信息 [32, 42]。然而，在数据有限的情况下，基于体素级输入的卷积神经网络模块可能难以从头训练。第三类方法保留静态功能连接特征作为输入，同时利用循环神经网络模块直接编码血氧水平依赖信号，以补充动态特征 [42]。除了模型复杂度较高之外，这类方法还可能受到循环神经网络固有局限的影响：在典型的功能磁共振成像扫描中，时间步数量庞大，容易出现梯度消失或梯度爆炸 [64, 65]。值得注意的是，这些既有方法的共同特点是主要考察脑区间瞬时相关性的时间变化。然而，由于缺少明确机制来捕捉层级处理或血流动力学延迟可能引起的区域间延迟相互作用，这些方法的敏感性可能并不理想 [45]。

在此，我们提出集成一种新型插件式图神经网络 GraphCorr，以提升下游功能磁共振成像分析模型的时间敏感性。所提出的 GraphCorr 方法采用新型节点嵌入模块，根据窗口化血氧水平依赖信号的瞬时相关性，提取动态功能连接特征的上下文嵌入；并采用新型滞后滤波模块，计算窗口化血氧水平依赖信号在各种时间延迟下的互相关特征嵌入。通过在图上执行消息传递算法，GraphCorr 可提供

增强的输入特征，在保留脑区之间动态延迟相关性的同时，提供给下游分析模型，从而提升其性能。不同于基于静态功能连接特征的方法 [17, 18], GraphCorr 利用动态功能连接特征捕捉脑区之间连接性的变化。不同于接收多个独立时间窗中多组动态功能连接特征的方法 [66, 42, 28], GraphCorr 融合不同时间窗的节点特征，在不牺牲性能的情况下降低模型复杂度。不同于采用需要顺序处理的循环架构的方法[42], GraphCorr 在动态功能连接特征上采用 Transformer 编码器，实现高效并行处理。不同于仅关注瞬时信号相关性的方法[17], GraphCorr 采用显式滞后滤波机制，学习脑区之间延迟的互相关。

3. GraphCorr

fMRI时间序列的分析流程通常首先依据解剖图谱，在整个大脑中定义一组R 个感兴趣区 (ROI) [18, 42]。随后，对每个ROI内的体素级血氧水平依赖信号取平均，以获得感兴趣区级信号，从而得到$\mathbf{B} \in \mathbb{R}^{R\times T}$ 这一血氧水平依赖信号矩阵，其中T 表示时间帧数。传统上，静态功能连接特征基于各ROI间这些血氧水平依赖信号的皮尔逊相关系数计算：相关系数：$\textbf{静态功能连接}_{i,\ j} = \mathrm{Corr}(\mathbf{B}_{i,\ \cdot}, \mathbf{B}_{j,\ \cdot})$, 其中$\textbf{静态功能连接} \in \mathbb{R}^{R\times R}$和$i$、$j$分别为ROI索引。许多以往的传统方法和基于学习的方法都使用下游分类模型处理静态功能连接特征，导致时间敏感性欠佳。为此，我们提出基于一种新颖的图神经网络插件，从血氧水平依赖信号中提取动态功能连接特征，并利用这些增强特征提升下游分类模型的性能。所提出的GraphCorr方法构建图结构来表示脑连接特征，利用节点嵌入器和滞后滤波模块捕捉血氧水平依赖信号中的动态滞后相关，最后在图上执行消息传递以计算增强特征（图1）。下文将介绍GraphCorr的方法组成部分及其流程。

3.1. 图构建

作为一种学习基底，GraphCorr 首先构建图 G(N, E)，其中 N 和 E 分别表示节点和边。节点集 $\mathrm{N} = \{\mathrm{r}_i \,|\, \mathrm{i} = 1, ..., \mathrm{R}\}$ 包含根据图谱定义的感兴趣区域，而二元边集定义为 $\mathrm{E} = \{\mathrm{e}_{i,j} = 1 \,|\, \mathrm{i} = 1, ..., \mathrm{R}; \mathrm{j} \in \mathcal{N}(\mathrm{i})\}$，其中 $\mathcal{N}(\mathrm{i})$ 是第 i 个节点的邻域。边通过阈值化定义：保留静态功能连接（sFC）中最强的 z% 相关系数，同时排除自连接，从而得到 E_n 条边。节点特征 $\mathrm{F} = \{\mathrm{f}_i \,|\, \mathrm{i} = 1, ..., \mathrm{R}\}$ 初始化为各对应节点的窗口化血氧水平依赖信号，以捕捉功能磁共振成像时间序列中的局部动态。为此，将包含 T 个时间帧的扫描划分为 W 个窗口，每个窗口大小为 T_w，步幅为 s：

$$W = \lfloor \frac{T - T_w}{s} \rfloor, \tag{1}$$

从而得到特征张量 $\mathbf{F} \in \mathbb{R}^{R\times T_w \times W}$。

3.2. 架构

为灵敏地提取动态连接特征，GraphCorr采用了一种新颖的节点嵌入模块。为捕捉延迟连接特征，GraphCorr还采用了一种新颖的滞后滤波模块。以下将详细介绍这两个模块。

节点嵌入模块：该模块以时间窗化 BOLD 信号为输入，计算动态功能连接特征的潜在表示（图 2）。首先，从时间窗化 BOLD 信号中提取动态功能连接特征，如下所示：$\mathrm{FC}_{i,j,w} = \mathrm{Corr}(\mathrm{F}_{i,\cdot,w}, \mathrm{F}_{j,\cdot,w})$，其中 $\mathrm{w} \in \{1, ..., \mathrm{W}\}$ 表示窗口索引，$\mathrm{i} \in \{1, ..., \mathrm{R}\}$，$\mathrm{j} \in \{1, ..., \mathrm{R}\}$ 表示节点索引。随后，使用 Transformer 编码器处理这些功能连接特征，其中 fMRI 时间序列中的各个窗口对应于 Transformer 标记序列。通过可学习线性投影 f_q、f_k 和 f_v得到特定窗口的键 $\mathrm{K}_w \in \mathbb{R}^{R\times d}$、查询 $\mathrm{Q}_w \in \mathbb{R}^{R\times d}$ 和值 $\mathrm{V}_w \in \mathbb{R}^{R\times d}$，并据此执行注意力计算：

$$\begin{aligned} Q_w &= U_q(\{\mathbf{FC}_{1,\cdot,w}, \mathbf{FC}_{2,\cdot,w}, ..., \mathbf{FC}_{R,\cdot,w}\}), \\ K_w &= U_k(\{\mathbf{FC}_{1,\cdot,w}, \mathbf{FC}_{2,\cdot,w}, ..., \mathbf{FC}_{R,\cdot,w}\}), \\ V_w &= U_v(\{\mathbf{FC}_{1,\cdot,w}, \mathbf{FC}_{2,\cdot,w}, ..., \mathbf{FC}_{R,\cdot,w}\}), \end{aligned} \tag{2}$$

其中，d 表示每个注意力头的维度。上述计算可针对H 个注意力头分别进行。特定窗口的注意力矩阵$\mathbf{A}_w \in \mathbb{R}^{R\times R}$ 随后按如下方式得出 [67]:

$$\mathbf{A}_w = \mathrm{Att}(Q_w, K_w, V_w) = \mathrm{Softmax}(\frac{Q_w K_w^{\intercal}}{\sqrt{d}})V_w. \tag{3}$$

注意力矩阵沿注意力头维度拼接，并在经过层归一化后传递至 MLP 模块：

$$\mathbf{EMB}_w = \mathrm{MLP}(\mathbf{A}_w) = \mathrm{GELU}(\mathbf{A}_w\mathbf{M}_1)\mathbf{M}_2 \tag{4}$$

其中，$\mathbf{M}_1 \in \mathbb{R}^{(R\times D)}$ 和$\mathbf{M}_2 \in \mathbb{R}^{(D\times D)}$ 表示 MLP 模型参数，GELU 是高斯激活单元，$\mathbf{EMB} \in \mathbb{R}^{R\times D\times W}$ 表示特定窗口的节点嵌入，D 表示嵌入维度，且$D < R$。

滞后滤波模块：该模块以时间窗化 BOLD 信号为输入，计算不同时间延迟范围内的互相关特征（图 3）。为此，图构建阶段得到的初始节点特征会沿时间维度进行零填充：

$$\mathbf{X}_{i,\cdot,w} = [\mathbf{0}_{(1\times m)}, \mathbf{F}_{i,\cdot,w}, \mathbf{0}_{(1\times m)}]. \tag{5}$$

其中，$\mathbf{X} \in \mathbb{R}^{R\times(T_w+2_m)\times W}$，而$m$ 定义了模块将考虑的延迟范围$\tau \in \{-m、\ -m+1、\ ....、\ m-1、\ m\}$。首先，分别计算每个滞后值下由$e^{ij}$ 连接的节点对之间的互相关：

$$\rho_{i,j,w,\tau} = \mathrm{Corr}(\mathbf{X}_{i,\cdot,w}, \mathbf{X}_{j,\cdot,w}, \tau) \tag{6}$$

随后，使用可学习的延迟滤波器 $\mathbf{P}_{LF} \in \mathbb{R}^{(2m+1)\times k}$ 将互相关映射为延迟激活，其中 k 表示滤波器的数量：

$$\mathbf{LAG}_w = \mathrm{GELU}(\rho_{\cdot,\cdot,w,\cdot}\mathbf{P}_{LF}) \tag{7}$$

其中$\mathbf{LAG} \in \mathbb{R}^{E_n\times W\times k}$ 表示特定于窗口的延迟激活。

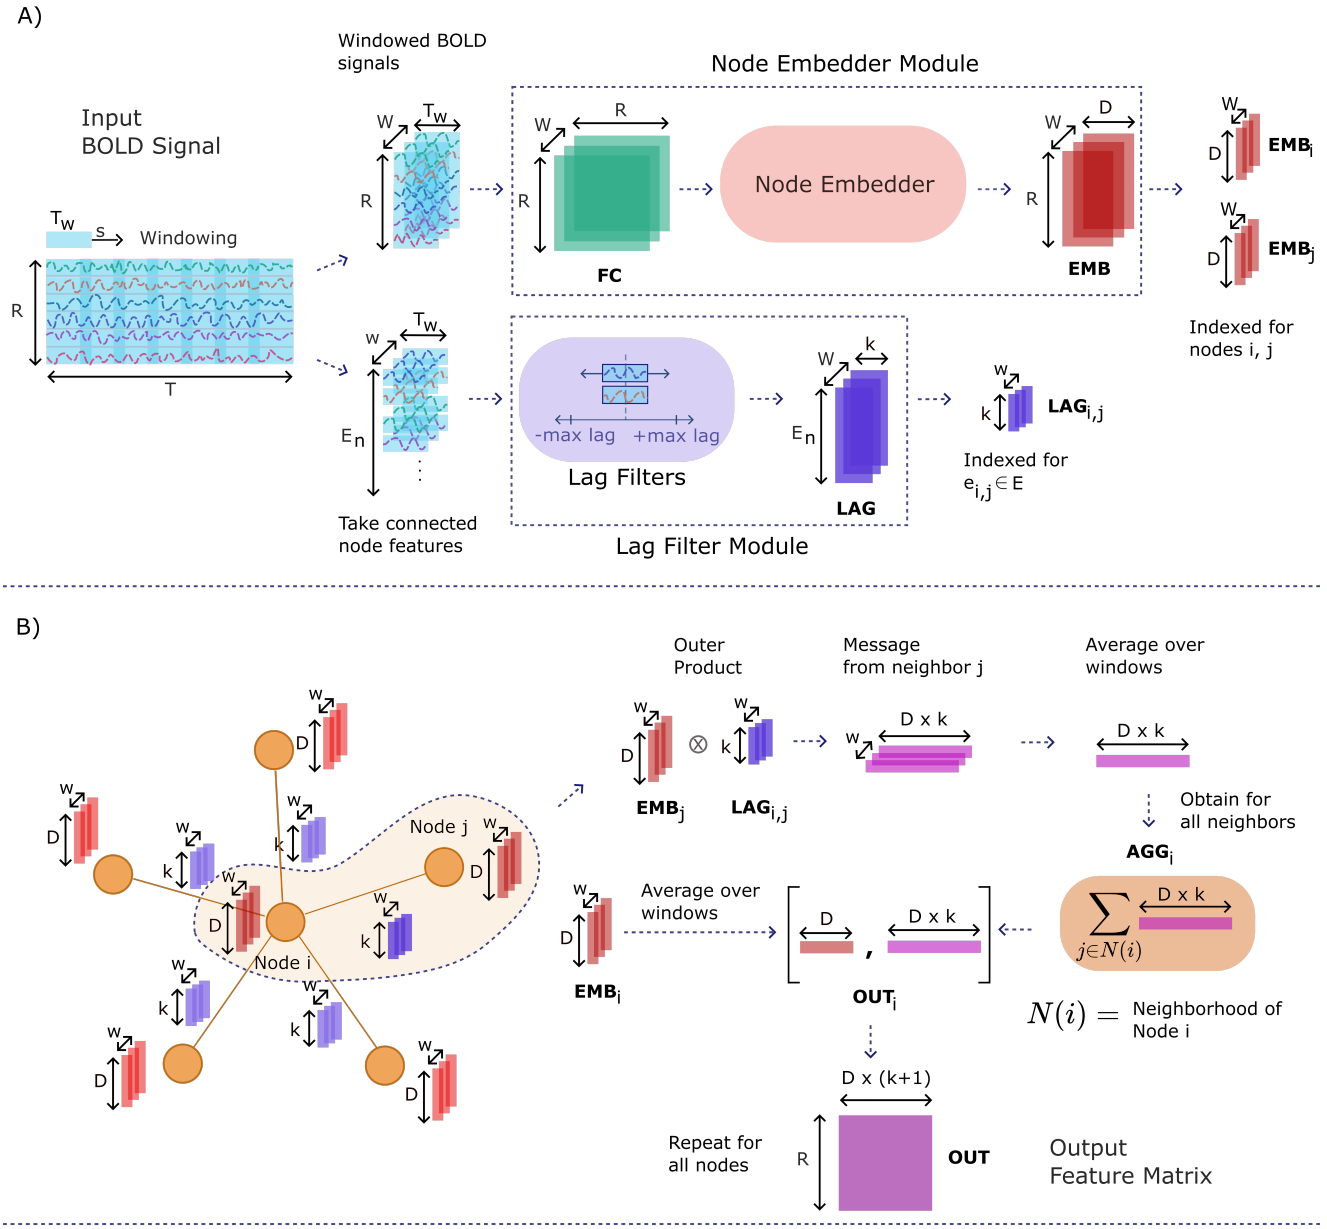


图 1：GraphCorr 概览。**A.** GraphCorr 利用两个并行模块，提取大脑中区域间相关性的动态滞后特征。节点嵌入模块接收时间窗化 BOLD 信号作为输入，并使用 Transformer编码器计算动态功能连接特征的节点嵌入 **EMB** $\in \mathbb{R}^{R\times D\times W}$。滞后滤波模块同样接收时间窗化 BOLD 信号作为输入，并计算一系列滞后值范围内由互相关产生的滞后激活 **LAG** $\in \mathbb{R}^{E_n\times W\times k}$。互相关仅针对相连节点对进行计算（$e_{i,j}=1$）。**B.** 为了在图上整合所提取的特征集，将节点嵌入作为节点特征，并将滞后激活作为边权重。随后在图上运行消息传递算法，在输出特征矩阵中生成增强的功能连接特征，**OUT** $\in \mathbb{R}^{R\times(D\times(k+1))}$。

3.3. 图学习

节点嵌入器会生成按时间窗口划分的节点嵌入，**EMB**，用于反映瞬时区域间相关性。滞后滤波器会生成按时间窗口划分的延迟激活，**LAG**，用于反映延迟的区域间相关性。为在图上整合这些特征集，将节点嵌入作为节点特征，并将延迟激活作为边权重（图1）。随后在图上运行消息传递算法，以计算增强的功能连接特征。为此，在成对的**MES** $\in \mathbb{R}^{R\times(D\times k)\times W}$ 之间计算消息张量

相连节点（r_i，r_j）：

$$\mathbf{MES}_{i,j,\cdot,w} = \mathbf{EMB}_{j,\cdot,w}\mathbf{LAG}^{\mathsf{T}}_{i,j,\cdot,w} \tag{8}$$

首先对各窗口中的消息取平均，然后将其传播到目标节点 r_i，该节点对来自一跳邻域节点 $j \in \mathcal{N}(i)$ 的所有消息求和：

$$\mathbf{AGG}_i = \sum_{j\in\mathcal{N}(i)} \frac{1}{W}\sum_{w=1}^{W} \mathbf{MES}_{i,j,\cdot,w}. \tag{9}$$

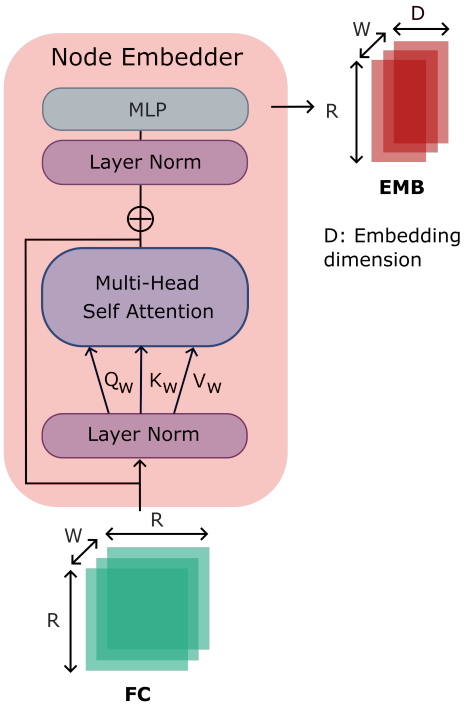


图 2 $\mathbb{R}^{R\times R}$ $\cdot_{\cdot,\cdot,w} \in$: 节点嵌入模块。在窗口 w 处的时间窗功能连接特征 **功能连接特征**$_{\cdot,\cdot,w}$经由包含多头自注意力（多头自注意力）、层归一化和多层感知机（多层感知机）层的Transformer编码器处理。输出为节点嵌入矩阵 $\mathbf{EMB}_{\cdot,\cdot,w} \in \mathbb{R}^{R\times D}$ 其中 $D < R$ 表示嵌入维度。

随后，将该聚合消息与 r_i 处经过窗口平均的节点嵌入拼接：

$$\mathbf{OUT}_i = [\frac{1}{W}\sum_{v=1}^{W}\mathbf{EMB}_{i,\cdot,w}, \mathbf{AGG}_i], \tag{10}$$

其中$\mathbf{OUT}_i \in \mathbb{R}^{D\times(k+1)}$ 表示r_i的增强特征。

4. 方法

4.1. 实验流程

演示使用了 HCP S1200 发布版的功能磁共振成像数据[1] [46]以及阿姆斯特丹开放式MRI数据集（AOMIC）的 ID1000 数据集[2] [47]。在 HCP数据集中，分析了静息态功能磁共振成像扫描的预处理数据。针对每位受试者，选取四个时段中的首个静息态扫描，并排除时长较短、$T < 1200$的扫描。最终共纳入 1093 名健康受试者（594 名女性和 499 名男性）。在 ID1000 数据集中，分析了观看电影期间记录的任务态功能磁共振扫描预处理数据。所有扫描的固定时长为 $T = 240$。共检查了 881 名健康受试者（458 名女性和 423 名男性）。对于这两个数据集，研究采用了两种备选的感兴趣区定义，分别基于 Schaefer图谱 [68] 或 AAL图谱 [36]。Schaefer图谱包含$R = 400$ 个感兴趣区域，分布于 7 个内在网络中；而 AAL图谱定义了$R = 116$个感兴趣区域。

实验使用 PyTorch 框架，在一块 NVIDIA Titan Xp 图形处理器上进行。采用嵌套交叉验证流程，设置 5 个外层折和 1 个内层折。可采用域适应流程来提高可靠性 [69]。数据被划分为训练集（70%）、验证集（10%）和测试集（20%），各集合之间受试者不重叠。为公平比较，所有模型均使用相同的数据划分进行训练、验证和测试。所有模型均基于交叉熵损失进行训练。针对每个模型，选择超参数以最大化各验证集上的平均性能。在不同数据集和图谱中，均采用一组经观察可获得近乎最优性能的通用超参数 [70]。模型实现的详细信息见第 4.2节。

4.2. 比较分析

GraphCorr 在若干基于学习的方法中进行了验证，这些方法作为下游分类模型，包括 SAGE[48], 图卷积网络 [29], BrainGNN [18], 和 BrainNetCNN [17]。对于每种方法，均通过将静态功能连接特征作为模型输入来训练基础下游模型；另行训练增强下游模型，并将 GraphCorr 用作插件以提供模型输入。原始模型和增强模型采用相同的训练流程。在所有图模型中，给定脑图谱中的感兴趣区域被视为节点，随后根据血氧水平依赖信号的相关性进行边选择。保留相关系数位于前 $z = 2\%$ 的边，丢弃其余边。下文将讨论下游模型和 GraphCorr 的实现细节。

SAGE： 基于一个包含图卷积池化和全连接层的模块构建了一个图神经网络模型 [48]。SAGE 由两个串联的图模块组成，隐藏维度为 250，丢弃率为 0.5。交叉验证得到的超参数为：学习率 3×10^{-3}、20 个训练轮数、批次大小为 12。

图卷积网络： 图卷积网络是一种基于图卷积、池化和全连接层的图神经网络模型 [29]。图卷积网络由两个图模块级联而成，隐藏维度为 100，丢弃率为 0.5。交叉验证得到的超参数为：学习率 5×10^{-3}、训练轮数 30、批次大小 12。

BrainGNN： BrainGNN 是一种基于感兴趣区域感知图卷积、池化和全连接层的图神经网络模型 [18]。该模型使用一个图模块，隐藏维度为 100，丢弃率为 0.5。交叉验证得到的超参数为：学习率 8×10^{-4}、训练轮数 80、批次大小 16。

BrainNetCNN： BrainNetCNN 是一种基于卷积层的卷积神经网络模型，采用边到边和边到节点滤波器[17]。卷积层的隐藏维度为 32，丢弃率为 0.1。原始 BrainNetCNN 需要大小为 $R \times R$ 的二维输入，即静态功能连接矩阵。使用 GraphCorr 增强后，为了兼容性，其输入维度调整为 $R \times D(k+1)$。交叉验证得到的超参数为：学习率 2×10^{-4}、20 个训练轮数、批次大小 16。

[1] https://db.humanconnectome.org
[2] https://openneuro.org/datasets/ds003097/versions/1.2.1

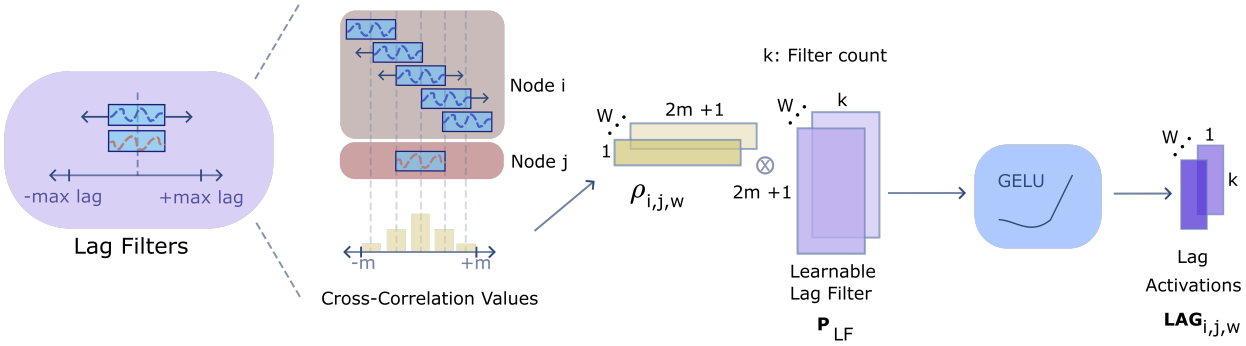


图 3：滞后滤波模块。在窗口 w 中，对延迟 $\tau \in \{-m、-m+1、\ldots\ldots、m-1、m\}$下的时间窗化 BOLD 信号进行互相关计算，其中$m$定义了范围。该计算仅针对相连节点对（$e_{i,j}=1$）进行。随后，互相关值 $\rho_{\cdot,\cdot,w,\cdot} \in \mathbb{R}^{R\times R\times(2m+1)}$通过可学习滤波器 $M_{LF} \in \mathbb{R}^{(2m+1)\times k}$ 线性变换为窗口特定的滞后激活 $\mathbf{LAG}_{\cdot,\cdot,w} \in \mathbb{R}^{R\times R\times k}$。

GraphCorr： 节点嵌入模块由单层 Transformer 编码器构成。由于 HCP 和 ID1000 的扫描时长不同，因此针对不同数据集分别选择T_w（窗口大小）和s（步幅），同时采用统一的m（最大滞后）和k（滤波器数量）。因此，交叉验证得到的参数为：HCP 使用（T_w=50，s=30，m=5，k=3），ID1000 使用（T_w=40，s=15，m=5，k=3）。

4.3. 解释性分析

为评估 GraphCorr 对可解释性的影响，我们考察了训练完成的下游模型的原始版本和增强版本。我们设计了解释流程，以识别 fMRI 时间序列中对模型决策贡献最显著的脑区。首先，采用基于梯度的方法计算显著性张量，以总结区域间相互作用 [71, 39]。对于原始模型，针对静态功能连接特征 **sFC**：

$$\mathbf{SAL}^{van}_{i,j} = |\nabla_{\mathbf{sFC}_{i,j}} y_{van}| \tag{11}$$

其中，$\mathbf{SAL}^{van} \in \mathbb{R}^{R\times R}$ 和y_{van} 表示模型预测。对于增强模型，计算相对于时间窗功能连接特征$\mathbf{FC}_{i,\ j,\ w}$的梯度：

$$\mathbf{SAL}^{aug}_{i,j,w} = |\nabla_{\mathbf{FC}_{i,j,w}} y_{aug}| \tag{12}$$

其中，$\mathbf{SAL}^{aug} \in \mathbb{R}^{R\times R\times W}$ 和y_{aug} 表示模型预测。随后，通过汇总各窗口的值并对显著性张量的感兴趣区域维度进行交互，计算出ROI特异性显著性分数：

$$\mathbf{rSAL}^{van} = \sum_{j=1}^{R} \mathbf{SAL}^{van}_{\cdot,j} \tag{13}$$

$$\mathbf{rSAL}^{aug} = \sum_{j=1}^{R} \left(\frac{1}{W}\sum_{w=1}^{W} \mathbf{SAL}^{aug}_{\cdot,j,w}\right) \tag{14}$$

其中 $\mathbf{rSAL}^{van,\ aug} \in \mathbb{R}^{R}$。在功能性脑网络层面评估显著性时，采用了 Schaefer图谱中定义的七个内在脑网络。对于每个网络，将网络内各区域的 ROI 特异性显著性分数取平均，得到每个半球的网络显著性分数。

表 1：采用Schaefer图谱时，下游模型在HCP和ID1000 数据集上的性能。结果以原始版本和GraphCorr增强版本在测试折上的均值±标准差列出。粗体表示每个模型中性能较佳的版本。

模型		HCP		ID1000	
		准确率 (%)	ROC (%)	准确率 (%)	ROC (%)
SAGE	原始	75.2 ± 2.84	85.29 ± 1.67	62.39 ± 2.17	68.59 ± 3.76
	增强	**89.57** ± 0.68	**94.27** ± 1.98	**81.7** ± 2.67	**87.02** ± 2。10
GCN	原始	79.14 ± 2.93	86.00 ± 1.47	67.84 ± 2.95	71.78 ± 3.88
	增强	**89.94** ± 2.18	**94.52** ± 1.61	**80.80** ± 0.98	**87.90** ± 1.75
BrainGNN	原始	72.83 ± 1.98	78.85 ± 2.45	62.50 ± 1.80	65.63 ± 2.81
	增强	**84.72** ± 1.33	**92.97** ± 0.98	**79.32** ± 1.96	**88.10** ± 2.19
BrainNetCNN	原始	82.52 ± 2.80	91.23 ± 1.21	75.45 ± 2.01	83.65 ± 2.05
	增强	**88.47** ± 2.63	**94.71** ± 1.86	**82.73** ± 1.63	**89.85** ± 2.24

虽然无符号的 ROI 特异性显著性分数反映了各区域对模型决策的相对重要性，但并未表明模型输出是由 ROI 内血氧水平依赖信号的增加还是减少所驱动。为探究这一问题，我们进行了事后逻辑回归分析。首先，通过沿 ROI 维度聚合显著性张量中的数值，确定 fMRI时间序列中的重要窗口：

$$\mathbf{wSAL}^{aug} = \sum_{i=1}^{R}\sum_{j=1}^{R} \mathbf{SAL}^{aug}_{i,j,\cdot} \tag{15}$$

$$w^{*} = \arg\max_{w} \mathbf{wSAL}^{aug} \tag{16}$$

此处，$\mathbf{wSAL}^{aug} \in \mathbb{R}^{W}$ 表示用于选择重要窗口的窗口特异性显著性分数。我们提取了最重要窗口内的血氧水平依赖信号，并根据强度进行阈值处理，以选出排名前 5 的时间帧 [72, 73, 35]。随后拟合一个逻辑回归模型，将跨感兴趣区域的血氧水平依赖信号向量映射到输出类别，即执行与下游模型相同的任务。逻辑回归模型会为每个感兴趣区域返回一个权重：正权重表示该感兴趣区域血氧水平依赖信号的增加会引发下游模型做出相应决策，而负权重则表示信号的减少会引发该决策。

表2：使用 AAL图谱时，下游模型在 HCP 和 ID1000 数据集上的性能。结果以原始版本和 GraphCorr 增强版本在各测试折上的均值±标准差列出。粗体表示各模型中表现较好的版本。

模型		HCP		ID1000	
		准确率（%）	ROC（%）	准确率（%）	ROC（%）
SAGE	原始	68.26 ± 3.31	75.65 ± 1.29	62.84 ± 1.81	67.23 ± 2.71
	增强	**85.45** ± 3.57	**91.19** ± 2.63	**77.50** ± 3.68	**84.92** ± 1.92
GCN	原始	69.90 ± 1.35	75.85 ± 1.06	65.45 ± 1.36	70.96 ± 1.23
	增强	**84.36** ± 3.17	**88.99** ± 2.83	**79.43** ± 3.45	**85.43** ± 2.49
BrainGNN	原始	65.69 ± 3.00	71.79 ± 2.97	62.27 ± 3.44	66.42 ± 4.24
	增强	**80.60** ± 2.67	**89.32** ± 2.67	**75.11** ± 0.56	**83.14** ± 1.41
BrainNetCNN	原始	68.16 ± 3.53	74.76 ± 2.08	75.00 ± 2.19	81.44 ± 3.27
	增强	**83.99** ± 2.92	**91.25** ± 2.65	**78.98** ± 1.83	**86.16** ± 0.84

5. 结果

5.1. 比较分析

我们在基于 SAGE [48]，图卷积网络 [29]，BrainGNN [18]，和 BrainNetCNN 的下游分类模型上验证了 GraphCorr [17]。我们使用各个受试者的静息态功能磁共振成像扫描执行性别检测任务。表1 列出了 HCP 和 ID1000 数据集上，下游模型原始版本与增强版本在 Schaefer图谱下的表现；表2 列出了 AAL图谱下的表现。在所有考察的情形中，采用 GraphCorr 进行增强均显著提升了下游模型的性能（p<0.05，Wilcoxon符号秩检验）。当感兴趣区域由 Schaefer图谱定义时，GraphCorr 使 HCP 上 SAGE 的（准确率，ROC）提升了（14.37，8.98）%，图卷积网络提升了（10.80，8.52）%，BrainGNN 提升了（11.89，14.12）%，BrainNetCNN 提升了（5.95，3.48）%；在 ID1000 上，SAGE 提升了（19.31，18.43）%，图卷积网络提升了（13.32，16.12）%，BrainGNN 提升了（16.82，22.47）%，BrainNetCNN 提升了（7.28，6.20）%。当感兴趣区域由 AAL图谱定义时，GraphCorr 使 HCP 上 SAGE 的性能提升了（17.19，15.54）%，图卷积网络提升了（14.46，13.14）%，BrainGNN 提升了（14.91，17.53）%，BrainNetCNN 提升了（15.83，16.49）%；在 ID1000 上，SAGE 提升了（14.66，17.69）%，图卷积网络提升了（13.98，14.47）%，BrainGNN 提升了（12.84，16.72）%，BrainNetCNN 提升了（3.98，4.72）%。我们观察到，原始版本中相对简单的图神经网络模型表现不及更复杂的 BrainNetCNN 模型。然而，经过 GraphCorr 增强的图神经网络模型开始优于增强后的 BrainNetCNN。因此，我们的结果表明，与基于卷积神经网络的架构相比，原始图神经网络模型的特征提取能力可能并不理想；不过，输入端强大的特征提取器可以弥补这一不足，使图神经网络模型受益。

5.2. 解释性分析

为评估 GraphCorr 对可解释性的影响，我们分别对训练完成的原始下游模型和增强下游模型进行了说明性分析。为此，我们选用了 HCP数据集和 Schaefer图谱；文献中已广泛使用它们研究静息态下的内在脑网络{v1}。

首先，我们比较了 SAGE 的原始版本和增强版本在各大脑半球中得到的网络显著性分数；经 GraphCorr 增强后，SAGE 通常仍保持最高性能。文献报告指出，感觉运动网络（SMN）、默认模式网络（DMN）和视觉网络在两个大脑半球中的血氧水平依赖信号均包含有关受试者性别的判别信息 [75, 39]。因此，我们认为，成功的性别检测下游分类模型应聚焦于这些网络。原始 SAGE 的结果表现出一定的异质性：左大脑半球（LH）的默认模式网络、右大脑半球（RH）的注意网络、感觉运动网络和视觉网络均呈现显著显著性；但出乎意料的是，它在两个大脑半球的边缘网络中也显示出较强的显著性（$p < 0.05$，Wilcoxon符号秩检验），尽管边缘网络被认为不包含性别相关信息。相比之下，增强 SAGE 在右大脑半球的感觉运动网络、默认模式网络和注意网络，以及两个大脑半球的视觉网络中均显示出显著性（$p < 0.05$），而边缘网络中则没有显著性。这些结果表明，GraphCorr 有助于提升下游分类模型的可解释性，使其能够聚焦于包含任务相关信息的脑区。

某个网络中的显著性分数显著，表明该网络中的血氧水平依赖信号包含有关受试者性别的信息。然而，这并不能说明不同性别个体的血氧水平依赖信号是升高还是降低。为了解决这一问题，我们根据 ROI 显著性分数，从重要性最高的时间窗口中提取血氧水平依赖信号，并对其进行逻辑回归分析。具体而言，我们拟合了一个逻辑回归模型，以重要的血氧水平依赖信号来判断受试者性别。图 4展示了逻辑回归模型中的 ROI 权重，其中正权重表示 ROI 中升高的血氧水平依赖信号与女性受试者相关，负权重则表示 ROI 中升高的血氧水平依赖信号与男性受试者相关。因此，我们检查了基于增强 SAGE 模型的逻辑回归分析中的 ROI 权重。女性受试者的右半球顶叶默认模式网络区域（包括后扣带皮层（PCC））、右半球前额叶默认模式网络区域、左半球前额叶控制区域以及左右半球躯体运动网络区域中，血氧水平依赖信号升高。男性受试者的左半球前额叶默认模式网络区域、左右半球背侧注意网络（DAN）、左半球顶叶和前额叶控制区域，以及右半球顶叶和纹外视觉区域中，血氧水平依赖信号升高。这些发现与相关证据一致：女性在包括 PCC 在内的默认模式网络区域中激活水平相对较高，而男性在视觉和注意区域中的激活水平相对较高 [76, 77]。我们的结果也与近期研究一致；这些研究表明，感觉运动网络和前额叶区域在两种性别中呈现不同的激活模式 [39]。

5.3. 消融研究 *s*

我们进行了消融研究，以评估 GraphCorr 中各个设计要素对模型性能的贡献。这些分析基于 SAGE模型，使用 HCP数据集和 Schaefer图谱进行，即

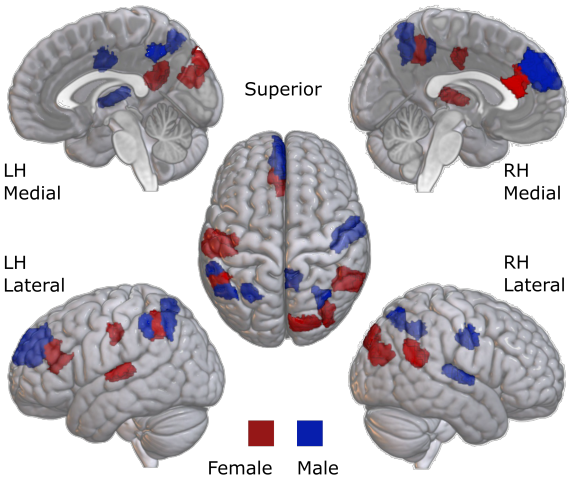


图 4：通过逻辑回归分析评估的性别检测显著感兴趣区域。在 HCP数据集上使用 Schaefer图谱的 GraphCorr 增强 SAGE模型的结果。标出了显著性分数排名前 2% 的感兴趣区域。红色表示女性受试者的血氧水平依赖信号较高的感兴趣区域，蓝色表示男性受试者的血氧水平依赖信号较高的感兴趣区域。

表 3：在采用 Schaefer图谱的 HCP数据集上，GraphCorr 各消融变体的性能。结果以跨测试折的均值±标准差表示，评估对象为下游SAGE模型。粗体表示表现最佳的变体。

Node 嵌入器	滞后滤波器	窗口化	准确率 (%)	ROC (%)
✗	✗	✗	75.20 ± 2.83	85.29 ± 1.67
✓	✗	✗	80.51 ± 1.92	88.49 ± 1.54
✓	✓	✗	81.16 ± 1.69	88.66 ± 2.07
✓	✓	✓	**89.57** ± 0。68	**94.27** ± 1。98

表4：使用 Schaefer图谱时，各插件方法在 HCP数据集上的表现。结果以测试折上的均值±标准差表示，适用于下游 SAGE模型。粗体表示表现最佳的插件。

插件	准确率（%）	ROC（%）
动态功能连接	81.06 ± 2.94	89.04 ± 1.53
LSTM	83.26 ± 2.05	90.29 ± 1.40
GRU	83.80 ± 2.29	92.12 ± 2.01
GraphCorr	**89.57** ± 0.68	**94.27** ± 1。98

在性别检测中整体性能最佳的设置。首先，我们评估了节点嵌入模块、滞后滤波模块和时间窗划分对 GraphCorr 的贡献。为消融节点嵌入模块，我们将消息传递前的节点嵌入初始化为通过对血氧水平依赖信号应用传统相关性度量得到的、未经学习的时间窗化 FC 矩阵。为消融滞后滤波模块，我们在该模块中仅使用一个零滞后滤波器，以仅考虑瞬时相关性。为消融时间窗划分，我们将整个 f MRI时间序列作为一个大小等于扫描时长的单一窗口输入 GraphCorr。表格 3 列出了 GraphCorr 消融变体的性能指标。结果表明，节点嵌入模块、滞后滤波模块和时间窗划分分别使（准确率，ROC）提升了（5.31，3.2）%、（0.65，0.17）% 和（8.41，5.61）%。

接下来，我们评估了相较于其他插件方法，GraphCorr 在提升下游模型时间敏感性方面的优势。具体而言，我们考虑通过传统相关性度量，为下游模型提供跨时间窗预先计算的动态功能连接特征 [66], 一种基于 LSTM 层的循环神经网络模型 [78], 以及一种基于 GRU 层的循环神经网络模型 [79]。所有插件模型的输出特征维度均与 GraphCorr 相同。表4 列出了不同插件方法的性能指标。GraphCorr 优于所有其他插件方法，其性能比排名第二的 GRU 方法高出 (5.77,2.15)% 。

6. 讨论

本文报告了一种新颖的即插即用图神经网络（GNN）方法 GraphCorr，通过捕捉血氧水平依赖信号的动态滞后 FC 特征，提升功能磁共振成像分析中下游分类模型的性能。我们在两个大型静息态 fMRI 数据集上进行了验证，结果显示，经 GraphCorr 增强后，模型性能显著提升。该方法可轻松与分类模型结合，用于检测与认知任务或疾病相关的其他类别变量 [18, 17]。或者，也可将其作为即插即用模块应用于下游回归模型，以提高预测与刺激或任务特征相关的连续变量的灵敏度 [1]。

神经影像学研究中的一种主流方法，是根据血氧水平依赖信号预测通常与刺激或任务相关的实验变量 [41, 51]。我们采用这一方法构建解码模型，以根据静息态功能磁共振成像扫描预测受试者性别。研究皮层功能的另一种方法是构建编码模型，与前者不同，它根据实验变量预测血氧水平依赖信号 [45, 80, 81]。或许可以采用 GraphCorr 提高此类下游编码模型的灵敏度。在这种情况下，GraphCorr 的输入将是功能磁共振成像扫描期间实验变量的时间序列。随后，它将学习实验变量之间的动态滞后相关，以更好地拟合其分布。学得的相关关系或许有助于提升下游回归模型的性能，这些模型旨在预测测得的血氧水平依赖信号。未来值得进一步研究 GraphCorr 在构建功能磁共振成像编码模型方面的潜力。

结合下游模型，GraphCorr 在包含数百名受试者数据的 HCP 或 ID1000 数据集上直接进行端到端训练。滞后滤波模块的复杂度较低，而节点嵌入模块使用了参数数量相对较多的 Transformer编码器。为改善在有限数据集上的学习效果，可以进行迁移学习，即使用预训练权重初始化编码器 [82]。能够根据学习到的分布生成大量多样化且真实样本的数据增强方法，或许还能进一步促进学习 [83, 84]。GraphCorr 首先构建一个图，并根据对应节点之间的静态功能连接值，在单跳邻域内保留边

。这种结构在后续训练过程中保持固定。为提升性能，也可以采用自适应结构，将边权重设为可学习参数。

在此，每位受试者的功能磁共振成像扫描均与解剖模板对齐，随后在脑图谱的指导下定义脑区。之后，将每个感兴趣区域中的平均血氧水平依赖信号输入下游模型进行处理。这种方法的优势包括：由于模型复杂度相对较低，计算效率较高；并且不同受试者的脑区定义保持一致 [85]。与此同时，将单个受试者的功能磁共振成像数据配准到标准化模板时，不可避免地会造成信息损失。为减少此类损失，可以将模板空间中的感兴趣区定义反投影到各个受试者的脑空间中。这样便可在保留功能磁共振成像数据原始空间的同时完成感兴趣区定义[51]。

7. 结论

本研究提出了一种新型插件式图神经网络，以提升下游模型在功能磁共振成像分类任务中的表现。所提出的 GraphCorr 方法采用节点嵌入器和滞后滤波模块，从全脑 fMRI 时间序列中灵敏地提取动态且滞后的功能连接特征。该方法将原始血氧水平依赖信号转换为图表示，其中相邻节点代表信号相关的脑区，而节点特征则通过在两个模块提取的连接性特征上进行消息传递获得。这一过程恢复了精细的时间信息，而这些信息在传统功能连接特征中可能会有所减弱。由于使用 GraphCorr 增强下游分类模型可显著提升其性能和可解释性，因此 GraphCorr 在 fMRI 时间序列分析方面具有广阔前景。

致谢

本研究部分获得以下资助：授予 H.A. Bedel 的 TUBITAK BIDEB 奖学金、TUBA GEBIP 2015 年奖学金、授予 T. C.ukur 的 BAGEP 2017 年奖学金以及 TUBITAK 121N029 项目资助。

参考文献

[1] C.ukur, T., Nishimoto, S., Huth, A.G., Gallant, J.L.. 自然视觉过程中的注意会扭曲人脑中的语义表征。《自然-神经科学》2013年;16(6):763–770。 [2] Yan, C.G., Chen, X., Li, L., Castellanos, F.X., Bai, T.J., Bo, Q.J., 等。复发性重度抑郁障碍患者的默认模式网络功能连接降低。《美国国家科学院院刊》2019年;116(18):9078–9083。 [3] He, Y., Lim, S., Fortunato, S., Sporns, O., Zhang, L., Qiu, J., 等。通过功能磁共振成像多尺度社团检测揭示重度抑郁障碍中的皮层网络重构。Cerebral Cortex 2018年;28(4):1383–1395。 [4] Bai, F., Zhang, Z., Yu, H., Shi, Y., Yuan, Y., Zhu, W., 等。默认模式网络活动可区分遗忘型轻度认知障碍与健康老龄化：一项结合结构性和静息态功能磁共振成像的研究。《神经科学快报》2008年;438(1):111–115。

[5] Yuan, Y., Zhang, Z., Bai, F., Yu, H., Shi, Y., Qian, Y., et al. 缓解期老年抑郁症患者的异常神经活动：一项静息态功能磁共振成像研究。《情感障碍杂志》2008年;111(2-3):145–152. [6] Cambria, E., Livingstone, A., Hussain, A.. 情绪沙漏。载于：认知行为系统。Springer; 2012, p. 144–157. [7] Andreu-Perez, J., Poon, C.C., Merrifield, R.D., Wong, S.T., Yang, G.Z.. 健康大数据。IEEE生物医学与健康信息学杂志 2015年;19(4):1193–1208. [8] Zhang, B., Tian, D., Yu, C., Zhang, J., Tian, X., von Deneen, K.M., et al. 肥胖男性进食前的基线脑活动改变：一项静息态功能磁共振成像研究。《神经科学快报》2015年;584:156–161. [9] Gu, X., Cao, Z., Jolfaei, A., Xu, P., Wu, D., Jung, T.P., et al. 基于脑电图的脑机接口（BCI）：关于信号感知技术、计算智能方法及其应用的近期研究综述。IEEE/ACM计算生物学与生物信息学汇刊 2021年;18(5):1645–1666. [10] Yan, C.Q., Wang, X., Huo, J.W., Zhou, P., Li, J.L., Wang, Z.Y., et al. 原发性失眠患者全脑功能连接异常：一项静息态功能磁共振成像研究。《神经病学前沿》2018年;9:856.[11] Mourao-Miranda, J., Bokde, A.L., Born, C., Hampel, H., Stetter, M.. 脑状态分类与判别性激活模式的确定：在功能磁共振成像数据上使用支持向量机。NeuroImage 2005;28(4):980–995. [12] Rashid, B., Arbabshirani, M.R., Damaraju, E., Cetin, M.S., Miller, R., Pearlson, G.D., et al. 利用静态与动态静息态功能磁共振脑连接对精神分裂症和双相障碍患者进行分类。NeuroImage 2016;134:645–657. [13] Dosenbach, N.U., Nardos, B., Cohen, A.L., Fair, D.A., Power, J.D., Church, J.A., et al. 利用功能磁共振成像预测个体脑成熟度。《科学》2010年;329(5997):1358–1361. [14] Rosenberg, M.D., Finn, E.S., Scheinost, D., Papademetris, X., Shen, X., Constable, R.T., et al. 基于全脑功能连接的持续性注意神经标志物。《自然-神经科学》2016年;19(1):165–171. [15] Liu, W., Wang, Z., Liu, X., Zeng, N., Liu, Y., Alsaadi, F.E.. 深度神经网络架构及其应用综述。《神经计算》2017年;234:11–26. [16] Plis, S.M., Hjelm, D.R., Salakhutdinov, R., Allen, E.A., Bockholt, H.J., Long, J.D., et al. 神经影像学深度学习：一项验证研究。Frontiers in Neuroscience 2014;8:229.[17] Kawahara, J., Brown, C.J., Miller, S.P., Booth, B.G., Chau, V., Grunau, R.E., et al. Brainnetcnn：用于脑网络的卷积神经网络；迈向神经发育预测。NeuroImage 2017;146:1038–1049. [18] Li, X., Zhou, Y., Dvornek, N., Zhang, M., Gao, S., Zhuang, J., et al. Braingnn：用于功能磁共振成像分析的可解释脑图神经网络。Medical Image Analysis 2021;74:102233. [19] Heinsfeld, A.S., Franco, A.R., Craddock, R.C., Buchweitz, A., Meneguzzi, F.. 利用深度学习和ABIDE数据集识别孤独症谱系障碍。NeuroImage: Clinical 2018;17:16–23. [20] Kim, J., Calhoun, V.D., Shim, E., Lee, J.H.. 具有权重稀疏性控制和预训练的深度神经网络可提取层次特征并提升分类性能：来自精神分裂症全脑静息态功能连接模式的证据。NeuroImage 2016;124:127–146. [21] Shen, H., Wang, L., Liu, Y., Hu, D.. 利用功能磁共振成像的低维嵌入对精神分裂症静息态功能连接模式进行判别分析。NeuroImage 2010;49(4):3110–3121. [22] Eslami, T., Saeed, F.. Auto-ASD-network：一种基于深度学习和支持向量机、利用功能磁共振成像数据诊断孤独症谱系障碍的技术。载于：第10届ACM生物信息学、计算生物学与健康信息学国际会议论文集。2019, p. 646–651. [23] Hjelm, R.D., Calhoun, V.D., Salakhutdinov, R., Allen, E.A., Adali, T., Plis, S.M.. 用于神经影像学的受限玻尔兹曼机：在识别内在网络中的应用。NeuroImage 2014;96:245–260.[24] Zhao, Y., Dong, Q., Zhang, S., Zhang, W., Chen, H., Jiang, X., et al. 利用三维卷积神经网络自动识别功能磁共振成像衍生的功能网络。IEEE生物医学工程汇刊 2017;65(9):1975–1984. [25] Meszl´enyi, R.J., Buza, K., Vidny´anszky, Z.. 基于静息态功能磁共振成像功能连接的卷积神经网络架构分类研究。

能连接分类。Frontiers in Neuroinformatics 2017;11:61. [26] Shao, L., Fu, C., You, Y., Fu, D.. 基于深度学习的功能磁共振成像数据自闭症谱系障碍分类。Cognitive Neurodynamics 2021;15(6):961–974. [27] Saeidi, M., Karwowski, W., Farahani, F.V., Fiok, K., Hancock, P., Sawyer, B.D., et al. 考虑个体差异的图神经网络任务态功能磁共振成像数据解码。Brain Sciences 2022;12(8):1094. [28] Gadgil, S., Zhao, Q., Pfefferbaum, A., Sullivan, E.V., Adeli, E., Pohl, K.M.. 用于静息态功能磁共振成像分析的时空图卷积。载于：国际医学图像计算与计算机辅助干预会议。Springer; 2020, p. 528–538. [29] Kipf, T.N., Welling, M.. 基于图卷积网络的半监督分类。arXiv:160902907 2016;.[30] Qu, G., Hu, W., Xiao, L., Wang, J., Bai, Y., Patel, B., et al. 通过图深度学习分析脑功能连接。IEEE生物医学工程汇刊 2021;69(5):1696–1706. [31] Yu, X., Zhang, L., Zhao, L., Lyu, Y., Liu, T., Zhu, D.. 通过双路Transformer解耦时空脑功能网络。arXiv:220409225 2022;.[32] Malkiel, I., Rosenman, G., Wolf, L., Hendler, T.. 用于功能磁共振成像预测任务的Transformer预训练与微调。arXiv:211205761 2021;. [33] Nguyen, S., Ng, B., Kaplan, A.D., Ray, P.. 注意并解码：利用注意力模型解码四维功能磁共振成像任务状态。载于：Machine Learning for Health。PMLR; 2020, p. 267–279. [34] Dai, W., Zhang, Z., Tian, L., Yu, S., Wang, S., Dong, Z., et al. Brain-former：用于脑功能磁共振成像数据分类的混合卷积神经网络-Transformer模型。arXiv:220803028 2022;. [35] Bedel, H.A., Sıvgın, I., Dalmaz, O., Dar, S.U.H., Cukur, T.. BOLT：用于功能磁共振成像时间序列分析的融合窗口Transformer。arXiv:220511578 2022;.[36] Tzourio-Mazoyer, N., Landeau, B., Papathanassiou, D., Crivello, F., Etard, O., Delcroix, N., et al. 利用蒙特利尔神经学研究所单受试者脑磁共振成像的宏观解剖分区，在SPM中对激活区域进行自动解剖标记。NeuroImage 2002;15(1):273–289. [37] Rolls, E.T., Joliot, M., Tzourio-Mazoyer, N.. 在自动解剖标记图谱中实现眶额皮层的新分区。NeuroImage 2015;122:1–5. [38] Laird, A.R., Eickhoff, S.B., Kurth, F., Fox, P.M., Uecker, A.M., Turner, J.A., et al. 基于BrainMap数据库的激活似然估计元分析工作流程：迈向概率性脑功能图谱。Frontiers in Neuroinformatics 2009;:23. [39] Kim, B.H., Ye, J.C.. 理解用于静息态功能磁共振成像功能连接分析的图同构网络。Frontiers in Neuroscience 2020;:630.[40] Gan, J., Peng, Z., Zhu, X., Hu, R., Ma, J., Wu, G.. 基于多图融合的脑功能连接分析。Medical Image Analysis 2021;71:102057.[41] Norman, K.A., Polyn, S.M., Detre, G.J., Haxby, J.V.. 超越读心：功能磁共振成像数据的多体素模式分析。Trends in Cognitive Sciences 2006;10(9):424–430. [42] Kim, B.H., Ye, J.C., Kim, J.J.. 利用时空注意力学习脑连接组的动态图表示。神经信息处理系统进展 2021;34. [43] Savva, A.D., Mitsis, G.D., Matsopoulos, G.K.. 使用滑动窗口技术评估静息态功能磁共振成像中的动态功能连接。Brain and Behavior 2019;9(4):e01255. [44] Handwerker, D.A., Roopchansingh, V., Gonzalez-Castillo, J., Ban-dettini, P.A.. 功能磁共振成像连接性的周期性变化。NeuroImage 2012;63(3):1712–1719. [45] Celik, E., Keles, U., Kiremitci, ˙I., Gallant, J.L., Cukur, T.. 人脑中动态场景类别表征的皮层网络。Cortex 2021;143:127–147. [46] Van Essen, D.C., Smith, S.M., Barch, D.M., Behrens, T.E., Yacoub, E., Ugurbil, K., et al. WU-Minn人类连接组项目概述。NeuroImage 2013;80:62–79. [47] Snoek, L., van der Miesen, M.M., Beemsterboer, T., van der Leij, A., Eigenhuis, A., Steven Scholte, H.. 阿姆斯特丹开放磁共振成像集合：一个用于个体差异分析的多模态磁共振成像数据集。Scientific Data 2021;8(1):1–23.[48] Hamilton

, W., Ying, Z., Leskovec , J.. 关于……的归纳式表示学习

大型图。《神经信息处理系统进展》2017年；30. [49] Woolrich, M.W., Ripley, B.D., Brady, M., Smith, S.M.. 功能磁共振成像数据单变量线性建模中的时间自相关。NeuroImage 2001年；14(6):1370–1386. [50] Bolling, D.Z., Pitskel, N.B., Deen, B., Crowley, M.J., McPartland, J.C., Kaiser, M.D., et al. 自闭症儿童对规则违反的神经反应增强：与社会排斥情境进行比较。发展认知神经科学 2011年；1(3):280–294. [51] Shahdloo, M., Celik, E., Cukur, T.. 自然视觉搜索过程中语义表征的偏向竞争。NeuroImage 2020年；216:116383. [52] Bu, X., Hu, X., Zhang, L., Li, B., Zhou, M., Lu, L., et al. 探究不同静息态功能磁共振成像参数对强迫症的预测价值。转化精神病学 2019年；9(1):1–10. [53] Xie, S.y., Guo, R., Li, N.f., Wang, G., Zhao, H.t.. 基于 PCA 与支持向量机结合的脑功能磁共振成像处理与分类。载于：2009年国际神经网络联合会议。IEEE；2009年，第3384–3389页。[54] Wee, C.Y., Yap, P.T., Zhang, D., Denny, K., Browndyke, J.N., Potter, G.G., et al. 利用结构和功能连接网络识别轻度认知障碍个体。NeuroImage 2012年；59(3):2045–2056. [55] Smith, S.M., Vidaurre, D., Beckmann, C.F., Glasser, M.F., Jenkinson, M., Miller, K.L., et al. 基于静息态功能磁共振成像的功能连接组学。Trends in Cognitive Sciences 2013年；17(12):666–682. [56] Riaz, A., Asad, M., Alonso, E., Slabaugh, G.. DeepFMRI：用于基于功能磁共振成像进行注意缺陷多动障碍功能连接分析与分类的端到端深度学习。神经科学方法杂志 2020年；335:108506.[57] Zeng, L.L., Wang, H., Hu, P., Yang, B., Pu, W., Shen, H., et al. 利用功能连接磁共振成像和判别式深度学习进行多中心精神分裂症诊断分类。EBioMedicine 2018年；30:74–85. [58] Wu, Z., Pan, S., Chen, F., Long, G., Zhang, C., Philip, S.Y.. 图神经网络综合综述。IEEE Transactions on Neural Networks and Learning Systems 2020年；32(1):4–24. [59] Liu, X., Tian, Y., He, Q., Lee, W.C., McPherson, J.. 分布式图摘要。载于：第23届 ACM 信息与知识管理国际会议论文集。2014年，第799–808页。[60] Cai, D., He, X., Han, J., Huang, T.S.. 用于数据表示的图正则化非负矩阵分解。IEEE Transactions on Pattern Analysis and Machine Intelligence 2010年；33(8):1548–1560. [61] Han, P., Yang, P., Zhao, P., Shang, S., Liu, Y., Zhou, J., et al. GCN-MF：通过图卷积网络和矩阵分解识别疾病-基因关联。载于：第25届 ACM SIGKDD 知识发现与数据挖掘国际会议论文集。2019年，第705–713页。[62] Sako˘glu, ¨U., Pearlson, G.D., Kiehl, K.A., Wang, Y.M., Michael, A.M., Calhoun, V.D.. 一种评估动态功能网络连接及任务调制的方法：在精神分裂症研究中的应用。物理学、生物学与医学中的磁共振材料 2010年；23(5):351–366.[63] Allen, E.A., Damaraju, E., Plis, S.M., Erhardt, E.B., Eichele, T., Calhoun, V.D.. 追踪静息态下的全脑连接动态。Cerebral Cortex 2014年；24(3):663–676. [64] Pascanu, R., Mikolov, T., Bengio, Y.. 关于循环神经网络训练的难点。载于：国际机器学习会议。PMLR；2013年，第1310–1318页。[65] Ismail, A.A., Gunady, M., Pessoa, L., Corrada Bravo, H., Feizi, S.. 输入单元注意力可减轻循环神经网络的显著性消失。神经信息处理系统进展 2019年；32. [66] Zhang, Y., Zhang, H., Chen, X., Lee, S.W., Shen, D.. 利用静息态功能磁共振成像构建混合高阶功能连接网络以诊断轻度认知障碍。科学报告 2017年；7(1):1–15. [67] Dalmaz, O., Yurt, M., Cukur, T.. ResViT：用于多模态医学图像合成的残差视觉Transformer。IEEE Transactions on Medical Imaging 2022年；41(10):2598–2614. [68] Schaefer, A., Kong, R., Gordon, E.M., Laumann, T.O., Zuo, X.N., Holmes, A.J., et al. 基于内在功能连接磁共振成像对人类大脑皮层进行局部-全局分区。Cerebral Cortex 2018年；28(9):3095–3114. [69] Elmas, G., Dar, S.U., Korkmaz, Y., Ceyani, E., Susam, B., Ozbey, M., et al. 用于 MRI 重建的生成式图像先验联邦学习。IEEE Transactions on Medical Imaging 2022年；. [70] Dalmaz, O., Mirza, U., Elmas, G., ¨Ozbey, M., Dar, S.U., Ceyani, E.,

et al. 一个模型统合一切：多对比度 MRI 合成的个性化联邦学习。arXiv 预印本 arXiv:220706509 2022年；. [71] Arslan, S., Ktena, S.I., Glocker, B., Rueckert, D.. 通过谱卷积网络生成图显著性图：应用于基于脑连接的性别分类。载于：生物医学图像分析与医学成像及非成像模态融合中的图。Springer；2018年，第3–13页。[72] Tagliazucchi, E., Balenzuela, P., Fraiman, D., Montoya, P., Chialvo, D.R.. 用于估计静息态功能连接的自发 BOLD 事件触发平均值。《神经科学快报》2011年；488(2):158–163.[73] Tagliazucchi, E., Balenzuela, P., Fraiman, D., Chialvo, D.R.. 通过一种新颖的点过程分析揭示大规模脑 fMRI 动力学中的临界性。Frontiers in Physiology 2012年；3:15. [74] Smith, S.M., Beckmann, C.F., Andersson, J., Auerbach, E.J., Bijsterbosch, J., Douaud, G., et al. 人类连接组计划中的静息态功能磁共振成像。NeuroImage 2013年；80:144–168. [75] Zhang, C., Dougherty, C.C., Baum, S.A., White, T., Michael, A.M.. 功能连接可预测性别：静息态脑连接存在性别差异的证据。Human Brain Mapping 2018年；39(4):1765–1776. [76] Ritchie, S.J., Cox, S.R., Shen, X., Lombardo, M.V., Reus, L.M., Alloza, C., et al. 成年人大脑中的性别差异：来自英国生物样本库 5216 名参与者的证据。Cerebral Cortex 2018年；28(8):2959–2975. [77] Allen, E.A., Erhardt, E.B., Damaraju, E., Gruner, W., Segall, J.M., Silva, R.F., et al. 静息态网络多变量比较的基线。Frontiers in Systems Neuroscience 2011年；5:2. [78] Dvornek, N.C., Ventola, P., Pelphrey, K.A., Duncan, J.S.. 使用长短期记忆网络通过静息态功能磁共振成像识别自闭症。载于：医学影像机器学习国际研讨会。2017年，第362–370页。[79] Gao, Y., No, A.. 基于功能磁共振成像数据和循环神经网络的年龄估计。Applied Sciences 2022年；12(2):749. [80] Shahdloo, M., C¸ elik, E., ¨Urgen, B.A., Gallant, J.L., C¸ ukur, T.. 搜索视觉动作类别过程中语义表征的任务依赖性扭曲。Journal of Neuroscience 2022年；. [81] Anderson, A.J., Zinszer, B.D., Raizada, R.D.. 功能磁共振成像的表征相似性编码：通过基于模式的合成，利用刺激-模型相似性预测脑活动。NeuroImage 2016年；128:44–53. [82] Korkmaz, Y., Dar, S.U., Yurt, M., ¨Ozbey, M., Cukur, T.. 通过零样本学习的对抗式变换器进行无监督 MRI 重建。IEEE Transactions on Medical Imaging 2022年；. [83] Dar, S.U., ¨Ozt¨urk, S¸., Korkmaz, Y., Elmas, G., ¨Ozbey, M., G¨ung¨or, A., et al. 用于加速 MRI 重建的自适应扩散先验。arXiv:220705876 2022年；. [84] ¨Ozbey, M., Dar, S.U., Bedel, H.A., Dalmaz, O., ¨Ozturk, S¸., G¨ung¨or, A., et al. 利用对抗扩散模型进行无监督医学图像转换。arXiv:220708208 2022年；.[85] Flandin, G., Kherif, F., Pennec, X., Malandain, G., Ayache, N., Poline, J.B.. 利用脑分区技术提高功能磁共振成像数据的检测灵敏度。载于：国际医学图像计算与计算机辅助干预会议。Springer；2002年，第467–474页。